基于支持向量回归与多核集成的红外成像导引头抗干扰性能评估方法

葛辰杰[1],陆志沣[2],洪泽华[2],马 潮[1],余海鸣[2],赖 鹏[2],乔 宇[1],杨 杰[1]
(1. 上海交通大学 电子信息与电气工程学院,上海 200240; 2. 上海机电工程研究所,上海 201109)

摘 要:面对着日益复杂的对抗环境,红外成像导引头的抗干扰性能需要不断提高。如何全面、客观、准确地对红外成像导引头的抗干扰性能进行评估,是一项急需解决的难题。针对传统基于支持向量机的评估方法中单核学习能力的不足,提出了一种基于支持向量回归与多核集成的评估方法,该方法在抗干扰评估指标体系下得到了综合的抗干扰性能值,为红外成像导引头抗干扰性能评估提供了新的思路。该方法能够训练多个支持向量回归机并融合多个核函数的优势,充分利用了特征的多样性,进一步降低了回归误差。实验结果表明:该算法能够实现高效可靠的红外成像导引头抗干扰性能评估。

关键词:红外成像导引头; 性能评估; 支持向量回归; 多核学习
中图分类号:V 19 **文献标志码**:A **DOI**:10.19328/j.cnki.1006-1630.2019.05.013

Anti-interference Capability Evaluation Based on SVM Regression and Multi-kernel Boosting

GE Chenjie[1], LU Zhifeng[2], HONG Zehua[2], MA Chao[1], YU Haiming[2], LAI Peng[2], QIAO Yu[1], YANG Jie[1]
(1. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China; 2. Shanghai Electro-Mechanical Engineering Institute, Shanghai 201109, China)

Abstract: Due to the increasingly complex fighting environment, there is a great need to improve the anti-interference capability. Therefore, how to evaluate the anti-interference capability of infrared guidance system precisely, objectively and efficiently has currently become an urgent issue. Since traditional SVM-based methods are unable to learn the regression effectively with single kernel machine, we propose an automatic method to evaluate the anti-interference capability based on SVM regression and multi-kernel boosting, using the manual index system and empirical evaluation results as training samples. The proposed method relies on multiple kernel learning to take full advantage of multiple features, which reduces the overall regression error. Experimental results show the effectiveness and efficiency of the proposed method on anti-interference capability evaluation.

Keywords: infrared guidance system; capability evaluation; SVM regression; multi-kernel boosting

0 引言

红外干扰技术[1]特别是新型诱饵的出现和迅猛发展,一定程度上削弱了红外制导飞行器的效能,因此在红外制导系统的研制中引入红外成像导引头抗人工干扰的性能指标至关重要。当研制的飞行器在这些指标上满足一定的条件,未来生产出的飞行器才能够在目标施放各种干扰的条件下,仍然能够以一个较大的概率击中目标,这样该型号飞行器才具

收稿日期:2018-07-24;**修回日期**:2019-09-02
基金项目:航天先进技术联合研究中心技术创新项目基金(USCAST2015-13,USCAST2016-23, USCAST2016-8);上海航天科技创新基金(SAST2016008, SAST2017100,SAST2016085)
作者简介:葛辰杰(1991—),男,博士研究生,主要研究方向为图像处理、模式识别、机器学习。

备生产的资格。为提高旋转飞行器抗红外诱饵干扰的能力，确保其在复杂干扰环境中精确命中目标，唐善军等[2]研究了一种基于目标和红外诱饵运动模式的抗干扰方法。采用合适的方法对飞行器的整体性能指标进行评估[3-10]具有重要意义。首先，能够为指标的论证提供方法，在保证必需的综合作战能力的前提下，得到作战使用性能和战术技术指标的最佳结合；其次，能够为方案论证和方案评审提供方法，以便对不同导引头研制方案的优劣提出结论性建议；最后，能够为鉴定定型提供方法，方便和用类导引系统的作战能力做综合比较。

抗干扰评估指标集主要有导引头的固有性能指标和引入抗干扰措施后的性能改善指标[11]。红外导引头的固有性能指标包含陀螺漂移率、最小可分辨温差和瞬时视场等，主要来自陀螺仪、热像仪系统和光学系统这些硬件环境。引入抗干扰措施后的性能改善指标主要体现在制导的准确程度上，包含指标发现真实目标的时间、跟踪效率、跟踪精度、作用距离、抗欺骗式干扰有效概率、目标图像损失度等。

传统的基于支持向量机的评估方法大多训练单核的回归器，所以结果比较依赖核函数的经验选取。为了进一步提升支持向量回归器的学习性能，本文采用多核集成的思路，把多个不同核的支持向量回归器融合到一个框架，通过建立一种基于支持向量回归与多核集成的红外成像导引头抗干扰性能的评估方法，以确立抗干扰评估指标与抗干扰综合性能值之间的定量关系，为红外成像导引头的抗干扰性能评估提供新的思路。

1　基于支持向量机的抗干扰性能评估方法

支持向量机方法[12]是建立在统计学习理论基础上的，将最大分类面分类器思想和基于核的方法结合在一起寻求最佳泛化能力的分类算法。把支持向量机思想用于回归，通过求解凸优化问题来进行回归分析，得到指标向量和抗干扰性能总体评价量之间的映射关系，具有坚实的理论基础。

给定训练样本 $D=\{(\boldsymbol{x}_1,y_1),(\boldsymbol{x}_2,y_2),\cdots,(\boldsymbol{x}_m,y_m)\}$，其中，$x_i$ 表示 k 维指标向量，y_i 表示抗干扰性能总体评价量，希望得到一个形如 $f(x)=\boldsymbol{w}^{T}x+b$ 的回归模型，使得 $f(x)$ 与 y 尽可能接近，w 与 b 是待确定的模型参数。对于样本 (x,y)，传统回归模型通常直接基于模型输出 $f(x)$ 与真实输出 y 之间的差别来计算损失，当且仅当 $f(x)$ 与 y 完全相同时，损失才为零。与此不同，支持向量回归(SVR)假设能容忍 $f(x)$ 与 y 之间最多有 ε 的偏差，即仅当 $f(x)$ 与 y 之间的差别绝对值大于 ε 时才计算损失，于是 SVR 问题可形式化为

$$\min_{w,b}\frac{1}{2}\|\boldsymbol{w}\|^{2}+C\sum_{i=1}^{m}l_{\varepsilon}(f(\boldsymbol{x}_i)-y_i) \tag{1}$$

式中：C 为正则化常数；l_{ε} 为 ε 不敏感损失函数，可以表示为

$$l_{\varepsilon}(z)=\begin{cases}0 & |z|\leqslant\varepsilon\\ |z|-\varepsilon, & \text{其他}\end{cases} \tag{2}$$

引入松弛变量 ζ_i 与 $\hat{\zeta}_i$，上面的最小化问题可重写为

$$\min_{w,b,\zeta_i,\hat{\zeta}_i}\|\boldsymbol{w}\|^{2}+C\sum_{i=1}^{m}(\zeta_i+\hat{\zeta}_i) \tag{3}$$

$$\text{s.t. } f(\boldsymbol{x}_i)-y_i\leqslant\varepsilon+\zeta_i \tag{4}$$

$$y_i-f(\boldsymbol{x}_i)\leqslant\varepsilon+\hat{\zeta}_i \tag{5}$$

$$\zeta_i\geqslant 0,\hat{\zeta}_i\geqslant 0,i=1,2,\cdots,m \tag{6}$$

通过引入拉格朗日乘子，$\mu_i\geqslant 0,\hat{\mu}_i\geqslant 0,\alpha\geqslant 0,\hat{\alpha}_i\geqslant 0$，由拉格朗日乘子法可得到拉格朗日函数

$$L(\boldsymbol{w},b,\alpha,\hat{\alpha},\mu,\hat{\mu})=\frac{1}{2}\boldsymbol{w}^{2}+C\sum_{i=1}^{m}(\zeta_i+\hat{\zeta}_i)-\sum_{i=1}^{m}\mu_i\zeta_i-\sum_{i=1}^{m}\hat{\mu}_i\hat{\zeta}_i+\sum_{i=1}^{m}\alpha_i(f(x_i)-y_i-\varepsilon-\zeta_i)+\sum_{i=1}^{m}\hat{\alpha}_i(y_i-f(\boldsymbol{x}_i)-\varepsilon-\hat{\zeta}_i) \tag{7}$$

令 $L(\boldsymbol{w},b,\alpha,\hat{\alpha},\mu,\hat{\mu})$ 对 $\boldsymbol{w},b,\zeta_i,\hat{\zeta}_i$ 偏导分别为零，可得

$$\boldsymbol{w}=\sum_{i=1}^{m}(\hat{\alpha}_i-\alpha_i)\boldsymbol{x}_i \tag{8}$$

$$0=\sum_{i=1}^{m}(\hat{\alpha}_i-\alpha_i) \tag{9}$$

$$C=\alpha_i+\mu_i \tag{10}$$

$$C=\hat{\alpha}_i+\hat{\mu}_i \tag{11}$$

将式(11)代入拉格朗日函数，可得 SVR 的对偶问题

$$\max_{\alpha\,\hat{\alpha}}\sum_{i=1}^{m}y_i(\hat{\alpha}-\alpha_i)-\varepsilon(\hat{\alpha}+\alpha_i)-\frac{1}{2}\sum_{i=1}^{m}\sum_{j=1}^{m}(\hat{\alpha}_i-\alpha_i)(\hat{\alpha}_j-\alpha_j)x_i^{\mathrm{T}}x_j \tag{12}$$

$$\text{s.t. }\sum_{j=1}^{m}(\hat{\alpha}_i-\alpha_i)=0 \tag{13}$$

$$0 \leqslant \alpha_i, \hat{\alpha}_i \leqslant C \tag{14}$$

解出 $\alpha, \hat{\alpha}$ 后即可得 SVR 的解形，即

$$f(x) = \sum_{i=1}^{m} (\hat{\alpha}_i - \alpha_i) \boldsymbol{x}^{\mathrm{T}} \boldsymbol{x} + b \tag{15}$$

由于上述对偶需要满足 KKT 条件，即

$$\begin{cases} \alpha_i (f(\boldsymbol{x}_i) - y_i - \varepsilon - \zeta_i) = 0 \\ \hat{\alpha}_i (y_i - f(\boldsymbol{x}_i) - \varepsilon - \hat{\xi}) = 0 \\ \alpha_i \hat{\alpha}_i = 0, \zeta_i \hat{\zeta}_i = 0 \\ (C - \alpha_i) \zeta_i = 0, (C - \hat{\alpha}_i) \hat{\xi}_i = 0 \end{cases} \tag{16}$$

对每个样本 $(\boldsymbol{x}_i, \boldsymbol{y}_i)$，都有 $(C - \alpha_i)\zeta_i = 0$ 且 $\alpha_i (f(\boldsymbol{x}_i) - y_i - \varepsilon - \zeta_i) = 0$，于是在得到 α_i 后，若 $0 < \alpha_i < C$，则必有 $\zeta_i = 0$，进而有

$$b = y_i + \varepsilon - \sum_{i=1}^{m} (\hat{\alpha}_i - \alpha_i) \boldsymbol{x}_i^{\mathrm{T}} \boldsymbol{x}_i \tag{17}$$

选取多个或者所有满足 $0 < \alpha_i < C$ 的样本，通过式(20)求解出 b 后，取平均值就得到最终的 b。

为了增加所求得的分类器的分类性能，可以把样本从原始空间映射到一个更高维的特征空间，使得样本在这个特征空间线性可分。

令 $\emptyset(\boldsymbol{x})$ 表示将 $\boldsymbol{x}$ 映射后的特征向量，代入 SVR 的解可得

$$f(\boldsymbol{x}) = \sum_{i=1}^{m} (\hat{\alpha}_i - \alpha_i) \emptyset(\boldsymbol{x}_i)^{\mathrm{T}} \emptyset(\boldsymbol{x}) + b \tag{18}$$

因为直接计算样本映射到特征空间后的内积比较困难，而且特征空间可能维数很高，所以考虑核函数

$$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = < \emptyset(\boldsymbol{x}_i), \emptyset(\boldsymbol{x}_j) > = \emptyset(\boldsymbol{x}_i)^{\mathrm{T}} \emptyset(\boldsymbol{x}_j) \tag{19}$$

那么 $\boldsymbol{x}_i, \boldsymbol{x}_j$ 在特征空间的内积就等于其在原始空间中通过核函数计算的结果。SVR 的解可表示为

$$f(\boldsymbol{x}) = \sum_{i=1}^{m} (\hat{\alpha}_i - \alpha_i) K(\boldsymbol{x}, \boldsymbol{x}_i) + b \tag{20}$$

这样，对于每个新样本的指标向量，就可以通过训练出的 SVR 得到总的评价量。

2 基于多核集成的抗干扰性能评估算法

集成学习[13]是一种可将弱学习器提升为强学习器的算法。这类算法的工作机制是，首先从初始训练集中训练出一个基学习器；其次，根据学习器的表现对训练样本分布进行调整，使得先前基学习器做错的训练样本在后续受到更多关注；再次，基于调整后的样本分布来训练下一个基学习器，如此重复进行，直到基学习器的数目达到事先指定的值 J；最后将这个 J 个基学习器加权组合。

采用 4 种常用核函数(见表 1)训练 SVR，第 m 个核函数在第 j 次迭代中对应的回归误差可以表示为

$$\varepsilon_m^{(j)} = \sum_{i=1}^{n_s} w_{i,m}^{(j)} \Psi[\,|\, h_m(\boldsymbol{x}_i) - y_i \,| - \Delta] \tag{21}$$

式中：符号函数 $\Psi[r]$ 在 $r > 0$ 条件下等于 1，其余情况下等于 0；$w_{i,m}^{(j)}$ 是第 i 个训练样本 $\boldsymbol{x}_i$ 在第 m 个核函数第 j 次迭代下的系数；$h_m(\boldsymbol{x}_i)$ 是第 m 个核函数的 SVR 在训练样本 $\boldsymbol{x}_i$ 上输出。阈值 Δ 为对样本误差的容忍程度，其表达式为

$$\Delta = \left(\frac{1.5}{n_s}\right) \times \sum_{i=1}^{n_s} h_m(\boldsymbol{x}_i) - y_i^{\,2} \tag{22}$$

表 1 常用核函数

Tab.1 Kernel functions

名称	表达式	参数
线性核	$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = \boldsymbol{x}_i^{\mathrm{T}} \boldsymbol{x}_j$	—
多项式核	$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = (\boldsymbol{x}_i^{\mathrm{T}} \boldsymbol{x}_j)^d$	$d \geqslant 1$ 为多项式系数
高斯核	$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = \exp\left(-\frac{\boldsymbol{x}_i - \boldsymbol{x}_j^{\,2}}{2\sigma^2}\right)$	$\sigma > 0$ 为高斯核的带宽
Sigmoid 核	$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = \tanh(\beta \boldsymbol{x}_i^{\mathrm{T}} \boldsymbol{x}_j + \theta)$	tanh 为双曲正切函数，$\beta > 0, \theta < 0$

采用多核集成的 SVR 算法，就是在每次迭代中寻找最优核的学习器，最后把这些弱学习器加权结合成强学习器。每次迭代后，都要更新每个训练样本的分布，使上次错分样本被赋予更大的权值。具体算法包括以下。

1)输入：训练样本集 $\{\boldsymbol{x}_i, y_i\}_{i=1}^{n_s}$ 和核函数集合 $\{K_m\}_{m=1}^{nK}$；

2)对每个核函数，在整个样本集上训练单核 SVRh_m；

3)初始化每个样本的权值，$w_{i,m}^{(1)} = 1/n_s (i = 1, 2, \cdots, n_s, m = 1, \cdots, n_K)$；

4)初始化回归器 $F(\boldsymbol{x}) = 0$；

5)循环 $j = 1, J$；

(1)对每个 SVR h_m，计算回归误差 $\varepsilon_m^{(j)}$，从中选择最优的 SVR $H^{(j)} = \arg \min_{h_m} \{\varepsilon_m^{(j)}\}$，并且记 $\delta^{(j)} - \min_{h_m} \{\varepsilon_m^{(j)}\}$；如果 $\delta^{(j)} < 0.5$，计算最优学习器 $H^{(j)}$ 的权值 $\beta_{(j)} = \frac{1}{2} \ln \frac{1 - \delta^{(j)}}{\delta^{(j)}}$，更新回归器 $F \leftarrow F + \beta_{(j)}$

$H^{(j)}$，否则，跳出结束；更新训练样本的权值 $w_{i,m}^{(j+1)}=w_{i,m}^{(j)}\beta_{(j)}^{1-\Psi[|h_m(x_i)-y_i|-\Delta]}$，然后归一化所有权值；

6）结束循环；

7）最终的回归器 $F(\boldsymbol{x})=\sum_j\beta_{(j)}H^{(j)}(\boldsymbol{x})$；

8）输出：回归器 $F(x)$。

集成学习通过侧重于降低误差，把基于泛化性能相当弱的学习器进行很强的集成，能够取得比单核 SVR 更好的回归效果，以及更好的关于评估指标向量和评价量的映射关系。

3　实验结果

本实验采用的数据见表 2。将 2 组仿真数据在 2 种不同抗干扰算法下的性能指标进行测量。其中，中心定位误差是指算法检测到的目标中心和实际目标中心的偏差，目标与视场中心像素差体现了目标偏离视场中心的偏差，图像熵反映了图像的平均信息量，重叠率是检测到的目标区域与实际目标区域重合的比例，信噪比是目标背景的灰度对比度与噪声均方差的比值，单帧识别时间反映了算法的运行效率，压制比是干扰能量与目标能量的比值，投放角度、投放数量和投放间隔是干扰投放的相关参数，虚警概率和识别概率衡量了目标识别算法的准确性。通过归一化后，得到的结果如表 3 所示。

表 2　两组仿真数据在两种不同抗干扰算法下的性能指标

Tab.2　Performance of two sets of data under two different anti-jamming algorithms

类别	抗干扰算法 1		抗干扰算法 2	
	数据 1	数据 2	数据 1	数据 2
中心定位误差	4.472 1	3.601 5	4.121 7	2.236 1
目标与视场中心像素差	4.472 1	3.601 5	4.121 7	2.236 1
图像熵	0.380 5	5.058 7	0.380 5	5.058 7
重叠率	0.384 8	0.594 4	0.424 9	0.618 0
信噪比	45.094 6	2.790 9	45.094 6	2.790 9
单帧识别时间/s	1.785 4	1.355 7	2.056 5	1.355 7
压制比	181.596 6	1.379 1	181.731 5	1.379 1
投放角度	58.1	60.15	58.1	60.15
投放数量	6	6	6	6
投放间隔	98	98	98	98
虚警概率	0	0	0	0
识别概率	1	1	1	1

表 3　两组仿真数据在两种不同抗干扰算法下的性能指标(归一化后)

Tab.3　Performance of two sets of data under two different anti-jamming algorithms (after normalization)

类别	抗干扰算法 1		抗干扰算法 2	
	数据 1	数据 2	数据 1	数据 2
中心定位误差	0.380 226	0.500 880	0.428 787	0.690 106
目标与视场中心像素差	0.380 226	0.500 880	0.428 787	0.690 106
图像熵	0.069 955	0.930 045	0.069 955	0.930 045
重叠率	0.380 594	0.587 904	0.420 256	0.611 246
信噪比	0.058 283	0.941 717	0.058 283	0.941 717
单帧识别时间/s	0.544 886	0.413 746	0.627 623	0.413 746
压制比	0.007 903	0.992 466	0.007 166	0.992 466
投放角度	0.354 444	0.331 667	0.354 444	0.331 667
投放数量	0.5	0.5	0.5	0.5
投放间隔	0.022 222	0.022 222	0.022 222	0.022 222
虚警概率	1	1	1	1
识别概率	1	1	1	1

对归一化后的数据进行层次分析法的评估，得到红外成像导引头的抗干扰性能指数如表 4 所示，以此作为接下来进行机器学习的标签值。采用对原始数据增加信噪比 32 dB 高斯白噪声的方法，对原始数据扩充 8 倍，label 值仍然保持原始值。

表 4　层次分析法的评估结果

Tab.4　Results of analytic hierarchy process

类别	抗干扰算法 1		抗干扰算法 2	
	数据 1	数据 2	数据 1	数据 2
抗干扰性能指数	0.244 6	0.560 7	0.255 0	0.590 7

机采用数据集中 75%的数据进行训练，剩下 25%的数据进行测试，得到的评估结果见表 5。

以上结果表明，本文方法能够准确预测抗干扰性能值，并且误差也足够小。为了分析多核集成的优越性，分别采用 4 种核训练支持向量机，得到的均方误差见表 6。由表可见，本文多核集成的方法取得的效果优于其他 4 种核。

4　结论

本文分析了基于支持向量回归的红外成像导引头抗干扰性能评估方法，并且把线性支持向量机推广到核空间。在单核支持向量机的基础上，提出集

表 5 所提出方法的评估结果

Tab.5 Results of our method

类别	数据 1	数据 2	数据 3	数据 4	数据 5	数据 6	数据 7	数据 8
指标 1	0.510 4	0.363 0	0.498 6	0.690 1	0.387 3	0.400 5	0.716 7	0.380 1
指标 2	0.526 9	0.383 5	0.477 6	0.690 1	0.346 9	0.357 1	0.639 9	0.380 6
指标 3	0.931 4	0.069 0	0.953 7	0.930 0	0.046 4	0.064 9	0.908 8	0.051 2
指标 4	0.576 4	0.359 5	0.557 1	0.611 2	0.387 5	0.403 9	0.586 9	0.414 2
指标 5	0.910 9	0.041 7	0.998 6	0.941 7	0.014 8	0.065 5	0.915 6	0.046 4
指标 6	0.428 0	0.526 3	0.390 8	0.413 7	0.530 1	0.556 0	0.367 2	0.524 3
指标 7	1.009 6	0.015 9	1.000 0	0.992 5	0.031 9	0.015 6	1.018 8	0.053 1
指标 8	0.351 3	0.315 1	0.261 4	0.331 7	0.350 8	0.351 9	0.327 6	0.387 7
指标 9	0.508 3	0.505 5	0.461 8	0.500 0	0.495 2	0.467 4	0.491 2	0.484 8
指标 10	0.000 0	0.013 6	0.042 0	0.022 2	0.065 2	0.000 0	0.040 1	0.025 5
指标 11	1.037 7	1.016 9	0.984 6	1.000 0	1.017 9	0.967 5	1.014 2	0.988 4
指标 12	0.965 2	1.011 9	1.004 8	1.000 0	0.996 7	1.011 7	0.989 0	0.979 9
真实值	0.560 7	0.244 6	0.560 7	0.590 7	0.244 6	0.244 6	0.590 7	0.244 6
预测值	0.562 5	0.245 7	0.557 7	0.588 3	0.239 8	0.232 9	0.575 9	0.246 3
误差/%	0.322 2	0.457 3	0.540 2	0.406 0	1.953 1	4.779 7	2.506 0	0.690 0

表 6 多核集成与单核的对比结果

Tab.6 Comparison between multi-kernel boosting and single-kernel method

本文方法	线性核	多项式核	高斯核	Sigmoid 核
0.000 050	0.000 097	0.000 130	0.000 334	0.000 136

成各个单核支持向量机的思想，把这些弱分类器进行加权，而且每次迭代都致力于给错分样本更大的权重，最终得到单核分类器的权值。实验结果表明，本文提出的红外抗干扰性能评估方法能够有效地对各指标进行评估，并得到最终的评价结果。该方法对样本数量没有特别限制，因此适用于小样本情况。后续将完善干扰环境集和抗干扰算法集，采用针对大数据分析的方法，例如深度学习来研究红外成像导引头抗干扰性能评估。

参考文献

[1] 李立坤.精确制导技术现状及发展方向[J].航空兵器，2004(1)：1-4.

[2] 唐善军，杨贝尔，许凌飞，等.基于目标和红外诱饵弹运动模式的抗干扰技术研究[J]. 上海航天，2017，34(S1)：44-49.

[3] 刘永昌，吴鹏.未来光电精确寻的制导技术发展前景预测[J].现代防御技术，2003，31(6)：46-51.

[4] 高卫，黄惠明，李军.光电干扰效果评估方法[M].北京：国防工业出版社，2006.

[5] 韩培骏.红外导引系统抗干扰性能评估准则与方法研究[D].南京：南京航空航天大学，2012.

[6] 唐善军，王枫，陈晓东.红外导弹抗干扰能力指标体系和评估研究[J].上海航天，2017，34(4)：144-149.

[7] 贾秋锐，周立柱，孙媛媛.红外成像制导抗干扰分析[J].制导与引信，2010，31(1)：1-3.

[8] 刘明辉，杨峰，王磊，等.基于 SVR 的反舰导弹作战效能探索性评估方法[J]. 计算机仿真，2009，26(8)：9-12.

[9] 胡朝晖，闫杰.红外空空导弹抗干扰性能的综合评估方法研究[J].弹箭与制导学报，2009，29(1)：61-65.

[10] 韩本刚，董敏周，于云峰，等.用基于指数标度的层次分析法评估红外导弹导引头抗干扰性能[J]. 西北工业大学学报，2008，26(1)：69-73.

[11] 许友平，吴庆宪，姜长生，等.基于支持向量机的红外成像导引头抗干扰性能评估方法[J]. 电光与控制，2013，20(12)：6-9.

[12] SUYKENS J A K，VANDEWALLE J. Least squares support vector machine classifiers [J]. Neural Processing Letters，1999，9(3)：293-300.

[13] BACH F R，LANCKRIET G R，JORDAN M I. Multiple kernel learning，conic duality，and the SMO algorithm [C]// Proceedings of the Twenty-first International Conference on Machine learning. ACM，2004：6.

（本文编辑：应振华）